

Vorlesung 11b

Statistik von Anteilen

Ein Beispiel:

Große Population (♀ und ♂)
mit unbekanntem Weibchenanteil p

In einer Stichprobe vom Umfang $n = 53$ waren
23 Weibchen und 30 Männchen

Wie kann man p “mit Konfidenz” schätzen?

Hat man Grund, an der Hypothese “ $p = 1/2$ ” zu zweifeln?

Modellvorstellung:
rein zufälliges Ziehen
mit Zurücklegen:
Münzwurf

$X = (X_1, \dots, X_n)$ mit unbekanntem p

$k/n = 23/53$ wird gedeutet
als Ausgang der Zufallsvariablen

$$\hat{p} := \frac{1}{n}(X_1 + \dots + X_n) .$$

Wie groß p auch immer ist:

Der *Schätzer* \hat{p} hat Erwartungswert p
und Standardabweichung σ/\sqrt{n} , mit

$$\sigma = \sigma(p) := \sqrt{p(1-p)} .$$

Schätzung für σ :

$$\hat{\sigma} := \sqrt{\hat{p}(1-\hat{p})} .$$

Im Beispiel ergibt sich für $\hat{p} \pm \hat{\sigma}/\sqrt{n}$

der Wert 0.43 ± 0.068

typische Schwankung in der Schätzung von p

Es geht noch besser:

De Moivre - Laplace sagt:

Für nicht all zu kleines $np(1 - p)$ ist

$$\hat{p} \sim p + \frac{\sigma}{\sqrt{n}}Z$$

mit $Z \sim N(0, 1)$ - verteilt

$$\frac{\hat{p} - p}{\sigma/\sqrt{n}} \sim Z$$

also auch

$$\frac{\hat{p} - p}{\hat{\sigma}/\sqrt{n}} \sim Z$$

$$\mathbf{P}_p\left(-2 \leq \frac{\hat{p} - p}{\hat{\sigma}/\sqrt{n}} \leq 2\right) \approx \mathbf{P}(-1.96 \leq Z \leq 1.96) = 0.95 .$$

$$\left\{ -2 \leq \frac{\hat{p} - p}{\hat{\sigma}/\sqrt{n}} \leq 2 \right\} = \left\{ \hat{p} - 2\frac{\hat{\sigma}}{\sqrt{n}} \leq p \leq \hat{p} + 2\frac{\hat{\sigma}}{\sqrt{n}} \right\}$$

$$I := \left[\hat{p} - 2\frac{\hat{\sigma}}{\sqrt{n}}, \hat{p} + 2\frac{\hat{\sigma}}{\sqrt{n}} \right]$$

$$\mathbf{P}_p(p \in I) \approx 0.95$$

Man nennt I ein *Konfidenzintervall* für p ,
approximativ zum *Niveau* 0.95

Zum Merken:

Das Ereignis

$$\{|\hat{p} - p| \leq 2\hat{\sigma}/\sqrt{n}\}$$

hat ungefähr W'keit 0.95

(weil \hat{p} approximativ normalverteilt ist
mit EW p und Standardabweichung σ/\sqrt{n})

Also überdeckt das zufällige Intervall

$$I = \left[\hat{p} - 2\frac{\hat{\sigma}}{\sqrt{n}}, \hat{p} + 2\frac{\hat{\sigma}}{\sqrt{n}} \right]$$

den “wahren Parameter” p mit W'kt ungefähr 0.95.

In unserem Beispiel ergab sich das Intervall $[0.29, 0.57]$.

Verträgt sich die Hypothese “ $p = 1/2$ “ mit den Daten?

Die beobachtete Abweichung war

$$|k/n - 1/2| = |23/53 - 1/2| \approx 0.07$$

Wie wahrscheinlich ist unter unserer Hypothese eine

(mindestens) so große Abweichung ?

Für $p = 1/2$ ist $\sigma_{\hat{p}} = 1/\sqrt{4n}$,

in unserem Beispiel ist das 0.069.

$$\mathbf{P}(|Z| > 1) = 0.32$$

So etwas wird jedes dritte Mal vorkommen ...

Maximum-Likelihood-Schätzer am Beispiel des Münzwurfs:

(X_1, \dots, X_n) sei p -Münzwurf mit unbekanntem p

Beobachtet wird die Realisierung (a_1, \dots, a_n)

mit $k = a_1 + \dots + a_n$.

Unter allen p ist k/n derjenige Parameter, mit dem

$$\mathbf{P}_p(X_1 = a_1, \dots, X_n = a_n) = p^k (1 - p)^{n-k}$$

maximal ist.

Man sagt:

$$\frac{1}{n}(X_1 + \dots + X_n)$$

ist der Maximum-Likelihood-Schätzer für p .

Für $k = n$ (kein Misserfolg in n Versuchen) ergibt sich 1 als Maximum-Likelihood-Schätzung von p .

Das ist möglicherweise zu optimistisch.

Eine Alternative bietet der sogenannte *Bayes-Schätzer* (vgl Buch S. 127).

Hier denkt man an ein zweistufiges Experiment:

1. eine auf $[0, 1]$ uniform verteilte Zufallsvariable U
2. gegeben $\{U = u\}$ einen Münzwurf mit Erfolgswahrscheinlichkeit U .

$$\tilde{p} := \mathbf{E}[U|K] .$$

Erinnerung an Vorlesung 9b:

Z_1, Z_2, \dots sei ein Münzwurf mit uniform auf $[0, 1]$ verteiltem zufälligem Erfolgsparameter U ,

K_n sei die Anzahl der Erfolge in den ersten n Versuchen.

Gefragt ist nach $\mathbf{E}[U \mid K_n = k]$.

Wir wissen schon:

Die bedingte Dichte von U gegeben $\{K_n = k\}$ ist

$$\mathbf{P}_k(U \in du) = \frac{1}{\frac{1}{n+1}} \binom{n}{k} u^k (1-u)^{n-k} du$$

$$\begin{aligned}
\mathbf{E}[U \mid K_n = k] &= \int \frac{1}{\frac{1}{n+1}} \binom{n}{k} u^{k+1} (1-u)^{n-k} du \\
&= \frac{k+1}{n+2} \int \frac{1}{\frac{1}{n+2}} \binom{n+1}{k+1} u^{k+1} (1-u)^{(n+1)-(k+1)} du \\
&= \frac{k+1}{n+2}.
\end{aligned}$$

Man nennt dies auch den

Bayes-Schätzer für die Erfolgswahrscheinlichkeit

(bei a priori uniform verteilter Erfolgswahrscheinlichkeit).

Eine Beziehung zur Pólya-Urne:

Im Buch S. 113/114 liest man nach:

Ein Münzwurf (Z_1, Z_2, \dots)

mit uniform verteilter Erfolgswahrscheinlichkeit U

ist so verteilt wie die Folge der Zuwächse in Richtung Osten
in einer Nordost-Wanderung à la Pólya.

Also:

$$\mathbf{E}[U|K_n] = \mathbf{P}[Z_{n+1} = 1|K_n] = \frac{k + 1}{n + 2}.$$